Big Data: Perspektiven für Smart Grids und Smart Buildings

R. Mikut
Institut für Angewandte Informatik
Karlsruher Institut für Technologie
Hermann-von-Helmholtz-Platz 1, 76344 Eggenstein-Leopoldshafen
EMail: ralf.mikut@kit.edu

Zusammenfassung Dieser Beitrag gibt eine kurze Übersicht über aktuelle Trends auf dem Gebiet Big Data. Nach einer Klärung des Begriffs "Big Data" und einer Erläuterung der Entstehung großer Datenmengen werden anwendbare Methoden skizziert. Abschließend geht der Beitrag verstärkt auf gegenwärtig etablierte Anwendungen und zukünftige Anwendungspotenziale in den Gebieten intelligenter Gebäude ("Smart Buildings") und intelligenter Netze ("Smart Grids") ein.

Abstract This paper present a short survey about recent trends on the arising field of big data. After a definition and explanation of "Big Data" and a discussion why data sizes increase, appropriate methods to solve big data problems are introduced. In addition, recent applications and future potentials in smart buildings and smart grids are discussed.

1 Einführung

In den letzten Jahren hat auch in technischen Anwendungen eine Reihe von Themen große Aufmerksamkeit erlangt, die mit der Nutzung großer Datenmengen ("Big Data") und der umfassenden Digitalisierung von industriellen Prozessen ("Industrie 4.0") zu tun haben.

Industrie 4.0 [9, 43] steht für die sogenannte vierte industrielle Revolution (nach der Dampfmaschine, der Elektrifizierung/Massenproduktion und der Computerisierung). Das Ziel sind veränderte Wertschöpfungsketten, die auf der Verfügbarkeit *aller* relevanten Daten in Echtzeit und ihrer Vernetzung beruhen. Das schließt die Erfassung und Analyse heterogener Daten (Zeitreihen, Bilder, Videodaten, Audiodaten, Protokolldateien mit Events, Textdateien) und ihre Fusion ein.

In diesem Beitrag werden Anwendungsszenarios für Gebäudedaten und für die intelligente Vernetzung von technischen Infrastrukturen näher betrachtet. Mögliche Datenquellen sind hier Sensoren, die örtlich und zeitlich aufgelöste Daten u.a. über mechanische Verformungen, Innen- und Außentemperaturen, Feuchtigkeit sowie elektrische Leistung, Warmwasser-, Kaltwasser- und Gasmengen generieren. Dazu kommen Protokolldateien mit erkannten Events, die Aufschluss über strukturelle Änderungen im jeweils betrachteten System sowie über erkannte Fehlersituationen geben. Solche Daten haben großes Potenzial zur Analyse der Sicherheit von Gebäuden und Infrastrukturen sowie zur Optimierung in Richtung Nutzerzufriedenheit und effizientem Betrieb. Das gilt sowohl für einzelne Gebäude als auch für vernetzte Infrastrukturen, z.B. Energienetze (Smart Grids, [25]) oder intelligente Städte (Smart Cities, [47]).

Das Ziel dieses Beitrags besteht darin,

- den Begriff Big Data näher zu erläutern (Abschnitt 2),
- auf die zugrundeliegenden generischen Methoden einzugehen (Abschnitt 3) und
- die Anwendungsszenarien Smart Buildings (Abschnitt 4) und Smart Grids (Abschnitt 5) näher zu erläutern.

2 Was bedeutet "Big Data"?

Der Begriff "Big Data" [19, 94] hat seinen Ursprung eher in der Informatik und wird durch die folgenden Eigenschaften ("4Vs") definiert [53, 89, 63]:

1. Volume (Größe bzw. Datenmenge),
2. Velocity (erforderliche Geschwindigkeit beim Generieren, Einlesen, Auslesen oder Übertragen von Daten),
3. Variety (Vielfältigkeit oder Heterogenität, bezogen auf viele verschiedene Datentypen und zu vernetzende Systeme mit unterschiedlichen Eigenschaften) und
4. Veracity (Vertrauenswürdigkeit, bezogen auf den Anteil fehlerhafter, fehlender oder nur mit Unsicherheiten verfügbaren Daten wie z.B. Intervalldaten).

Große Datenmengen resultieren entweder aus extrem vielen Datentupeln N (z.B. bei Webzugriffen oder Protokolldateien mit Events) oder aus der Multidimensionalität, siehe Tabelle 1. Diese Multidimensionalität tritt sowohl bei Zeitreihen (große Anzahl von Abtastzeitpunkten K durch lange Aufzeichnungen und hohe zeitliche Auflösungen) als auch bei Bildern (viele Bildspalten und -zeilen I_x,I_y, evtl. mit einer zusätzlichen räumlichen Auflösung I_z) und Videos auf. In einigen Fällen kann auch die Anzahl s der Einzelmerkmale, Zeitreihen und Bilder eine entscheidende Rolle spielen, z.B. bei vielen Sensoren. Hinzu kommt die Tatsache, dass sich verschiedene Arten der Dimensionalität multiplikativ verknüpfen, z.B. bei Zeitreihen mit $s \cdot K$.

Big Data ist ein relativer Begriff: Probleme treten immer nur auf, wenn eine geplante oder bereits realisierte Anwendung in mindestens einem der obengenannten Punkte die verfügbare Software- und Hardwareinfrastruktur in einer Firma, einer Universität oder einer Forschungseinrichtung überfordert. Der Übergang zwischen klassischen Datenanalyseaufgaben und Big-Data-Aufgaben ist allerdings fließend, wenn Anwendungen an der Kapazitätsgrenze der bestehenden Infrastruktur liegen. Solche Aufgaben sind dann in der Regel mit klassischer Infrastruktur bei erhöhtem Aufwand und schlechter Performanz immer noch durchführbar, allerdings wäre eine spezielle, auf Big-Data-Aufgaben zugeschnittene Infrastruktur vorteilhaft.

3 Welche Methoden eignen sich im Umgang mit "Big Data"?

Prinzipiell basieren alle Analysemethoden für Big-Data-Probleme auf etablierten Datenanalysemethoden, die seit Jahrzehnten erfolgreich eingesetzt werden. Diese Methoden stammen sowohl aus der klassischen Statistik [5, 40] als auch aus dem Maschinellen Lernen und der

Tab. 1 Datensätze für verschiedene Arten von Rohmerkmalen. Abkürzungen: $l = 1, \ldots, s$ Nummer gleichartiger Merkmale; $n = 1, \ldots, N$ Datentupel; $k = 1, \ldots, K$ Abtastzeitpunkte; ID: Eindeutige Identifier eines Events; $i_{E1}, \ldots, i_{Es}$ Parameter von Events; $i_x = 1, \ldots, I_x$ Bildspalten; $i_y = 1, \ldots, I_y$ Bildzeilen; $i_z = 1, \ldots, I_z$ Bildschichten. Die niedrigeren Dimensionszahlen der Datensätze gelten für $s = 1$ (nur ein Einzelmerkmal, eine Zeitreihe, ein Bild bzw. ein Video) sowie ein Datentupel ($N = 1$), modifiziert nach [62].

Rohdaten	Dimension	Bestandteile	Anzahl Rohmerkmale s_{Roh} pro Datentupel
Einzelmerkmale	0-2	$x_l[n]$	s
Zeitreihen	1-3	$x_{ZR,l}[k,n]$	$s \cdot K$
Events	2	$x_{Event}[ID, i_{E_1}, \ldots, i_{E_s}, n]$	$E_s + 1$
Bilder	2-4	$x_{Bild,l}[i_x, i_y, n]$	$s \cdot I_x \cdot I_y$
3D-Bilder	3-5	$x_{Bild,l}[i_x, i_y, i_z, n]$	$s \cdot I_x \cdot I_y \cdot I_z$
Videobilder	3-5	$x_{Video,l}[i_x, i_y, k, n]$	$s \cdot I_x \cdot I_y \cdot K$
3D-Videobilder	4-6	$x_{Video,l}[i_x, i_y, i_z, k, n]$	$s \cdot I_x \cdot I_y \cdot I_z \cdot K$

Computational Intelligence [52, 61]. Beispiele für Verfahren des Maschinellen Lernens sind k-Nearest-Neighbor-Verfahren (Analyse der Ausgangsgröße ähnlicher Beispiele, [20]) und Support-Vektor-Maschinen (Suche optimaler Trennflächen in höherdimensionalen Räumen mit integrierten nichtlinearen Transformationen [16]). Zur Computational Intelligence gehören u.a. Künstliche Neuronale Netze [36], die biologisch inspirierte Verschaltungen einfacher Verarbeitungseinheiten zur Nachbildung nichtlinearer Zusammenhänge nutzen, und Cluster-Verfahren zur automatischen Suche nach ähnlichen Beispielen wie Fuzzy-C-Means [12, 39].

Dennoch ergeben sich bei Big-Data-Aufgaben in einigen Punkten Besonderheiten:

1. Es wird größerer Wert auf gut skalierende Algorithmen (z.B. mit geringerer Komplexität oder guter Parallelisierbarkeit) gelegt. Das ist insbesondere dann wichtig, wenn die Datenmengen schneller steigen als die Rechengeschwindigkeiten und Speicherkapazitäten der verfügbaren Infrastruktur.

2. Hierfür sind teilweise neue Implementierungen erforderlich, die für verteilte Umgebungen konzipiert sind und gut skalieren. Beispiele sind verteilte Filesysteme wie Hadoop, Analysetools wie Apache Spark und Tools zum Cloud Computing, siehe z.B. [23, 35, 80], sowie spaltenorientierte Datenbanken [73].

3. Zur Beherrschung multidimensionaler Daten werden geeignete Einzelmerkmale durch eine Merkmalsextraktion aus Zeitreihen und Bildern ermittelt, um Informationen in komprimierter Form enthalten. Auch diese Methoden sind seit langem bekannt, werden aber verstärkt eingesetzt. Darüber hinaus wird versucht, diesen Schritt durch integrierte Merkmalsextraktionen zu automatisieren, was oft unter dem Begriff Deep Learning zusammengefasst wird [55].

4. Verfahren zur automatischen Beurteilung der Daten- und Modellqualität [7, 59, 61, 72] spielen eine größere Rolle, weil die bisherigen halbautomatischen Techniken zur Datenbereinigung, Ausreißerdetektion und Modellvalidierung zu aufwändig werden und weil

bestimmte Datenqualitätseffekte durch Standardvalidierungsmethoden nicht erkannt werden, siehe z.B. [21].

5. Zur Beherrschung von Datenströmen (also kontinuierlich anfallenden Daten, engl. data streams) müssen rekursive Methoden eingesetzt werden, die Modelle ständig nachführen und mit neu hinzukommenden Daten verbessern [1].

Eine Auswahl typischer Datenanalysemethoden zeigt Tabelle 2. Für eine erfolgreiche Lösung müssen Fachexperten für das jeweilige Anwendungsgebiet und Fachexperten für Datenanalyse eng zusammenarbeiten, um die Fragestellung in der Anwendung in ein für Datenanalysemethoden lösbares Problem zu übersetzen und um die Ergebnisse zu interpretieren. Hierbei ist entscheidend, den kompletten Auswerteablauf durch geeignete Softwaretools [66] zu unterstützen und skriptbasiert zu automatisieren. Dazu existieren kommerzielle Produkte wie der IBM SPSS Modeler (*http://www.spss.com/software/modeling/modeler*) oder Open-Source-Lösungen wie KNIME (*http://www.knime.org*, [11]), Gait-CAD (*http://sourceforge.net/projects/gait-cad*, [17]), sowie neuere Big-Data-Tools wie Apache Spark (*http://spark.apache.org*, [60]).

Tab. 2 Ausgewählte Analysemethoden

Aufgaben	Ausgewählte geeignete Verfahren
Erkennung atypischer Werte (Ausreißer)	Klassifikation (k-Nearest Neighbor, Support-Vektor-Maschinen)
Fehlerdetektion	Klassifikation (Bayes-Klassifikatoren, Künstliche Neuronale Netze, Support-Vektor-Maschinen)
Prognose zukünftiger Werte einer Zeitreihe	Regression (Autoregressive Modelle mit oder ohne externe Eingänge, Künstliche Neuronale Netze, k-Nearest Neighbor)
Suche nach Zusammenhängen in Protokolldateien mit Events	Process Mining [85]
Suche nach Subgruppen und typischen Mustern	Cluster-Verfahren (Fuzzy-C-Means, Hierarchisches Clustern), Spezielle Visualisierungen
Verstehen wesentlicher Zusammenhänge	Korrelationsanalysen, Regression (Polynome, Künstliche Neuronale Netze), Spezielle Visualisierungen

Typische klassische Datenanalyseaufgaben und typische Big-Data-Aufgaben zeigt Tabelle 3. Auffällig sind dabei die extrem unterschiedlichen Anwendungsgebiete, die dennoch mit einem ähnlichen Satz an Methoden bearbeitet werden.

4 Smart Buildings (Intelligente Gebäude)

Auch Gebäude können große Datenmengen generieren. Je nach Anwendungsszenario sind hier unterschiedliche Fälle denkbar:

1. In vielen Gebäuden werden zunehmend Sensoren installiert, die Nutzungsdaten wie Energieverbrauch, Innentemperatur, Heizleistung, Wasserverbrauch, lokale Wetterdaten (z.B. Wind) usw. erfassen. Hier besteht ein Trend zu einer zunehmenden zeitlichen und örtlichen Auflösung. Während früher Zählerdaten in sehr großen Zeitabständen (z.B. einmal

Tab. 3 Typische klassische Datenanalyseaufgaben und Big-Data-Aufgaben

Aufgaben	Klassische Datenanalyseaufgaben	Big-Data-Aufgaben
Bauwesen	Bruchortung [38], Strukturanalysen mit zeitabhängigem Materialverhalten [29]	Echtzeitmonitoring-System für Gebäude [70]
Biologie	Herzschlagerkennung aus kurzen Videos [74]	Analyse von Gensequenzen [3, 86], 3D-Videobilder in der Mikroskopie [2, 48, 79]
Chemie	Entwurf antibakterieller Peptide [65]	3D-Strukturerkennung von Proteinen [30]
Ingenieurwesen	Greifplanung [10, 14], Prognose für Photovoltaik-Anlagen [28] und Windanlagen [15]	(Prädiktive) Fernwartung von Werkzeugmaschinen [8], Autonomes Fahren [90], Cloud Robotics [45], Humanoide Robotik [4], Smart Meter Daten [87], Phasordaten [58]
Medizin	Bewegungsanalysen [93], Bildverarbeitung [68], Brain-Machine-Interfaces [64, 67], Statistische Analysen [88], Rollstuhlsteuerung [76]	Personalisierte Medizin [33]
Physik	–	Elementarteilchenerkennung im Large Hadron Collider [13], Klimaforschung [24]
Sicherheits-technologien	Betrugserkennung [71]	Überwachung [57]
Wirtschafts-wissenschaften	Kundenbindungsanalysen [78]	Analyse sozialer Medien [83], Logistik [51]

pro Jahr) erfasst wurden, sind inzwischen viele diese Daten mit Abtastzeiten von 15 min verfügbar (siehe z.B. [34, 44, 69, 87]). Außerdem werden Sensordaten gespeichert, die früher nur in lokalen Regelkreisen (z.B. Temperaturmessung in einem Heizungsthermostat) verwendet wurden. Ein Ziel bei der Nutzung solcher Daten besteht darin, dem Nutzer ein Feedback über seine Verbrauchsdaten zu geben und so zur effizienten Nutzung zu motivieren [69, 84]. Darüber hinaus sind solche Daten auch für die Wartung und Fehlerdetektion interessant, weil sie atypische Verläufe anzeigen können, die z.B. auf kurzzeitige Ereignisse wie Sensorfehler, offene Fenster und abgedeckte Lüftungen [91] oder langfristig auftretende Effekte wie fehlerhafte Wärmeisolierungen hinweisen können.

Um typische Verbrauchsmuster aufzuzeigen ist es sinnvoll, Daten zu visualisieren oder Nutzersubgruppen mit Clusterverfahren zu identifizieren. Entsprechende Beispiele für die Visualisierung und Clusteranalysen zeigt Abb. 1.

2. Viele Kommunen oder Betreiber von Gebäuden (z.B. in Industriegewerbeparks) haben inzwischen umfangreiche Daten zur Beschreibung ihres Gebäudebestands, siehe z.B. [46]. Beispiele hierfür gehen von relativ einfachen Merkmalen (z.B. Baujahr, Grundflächen,

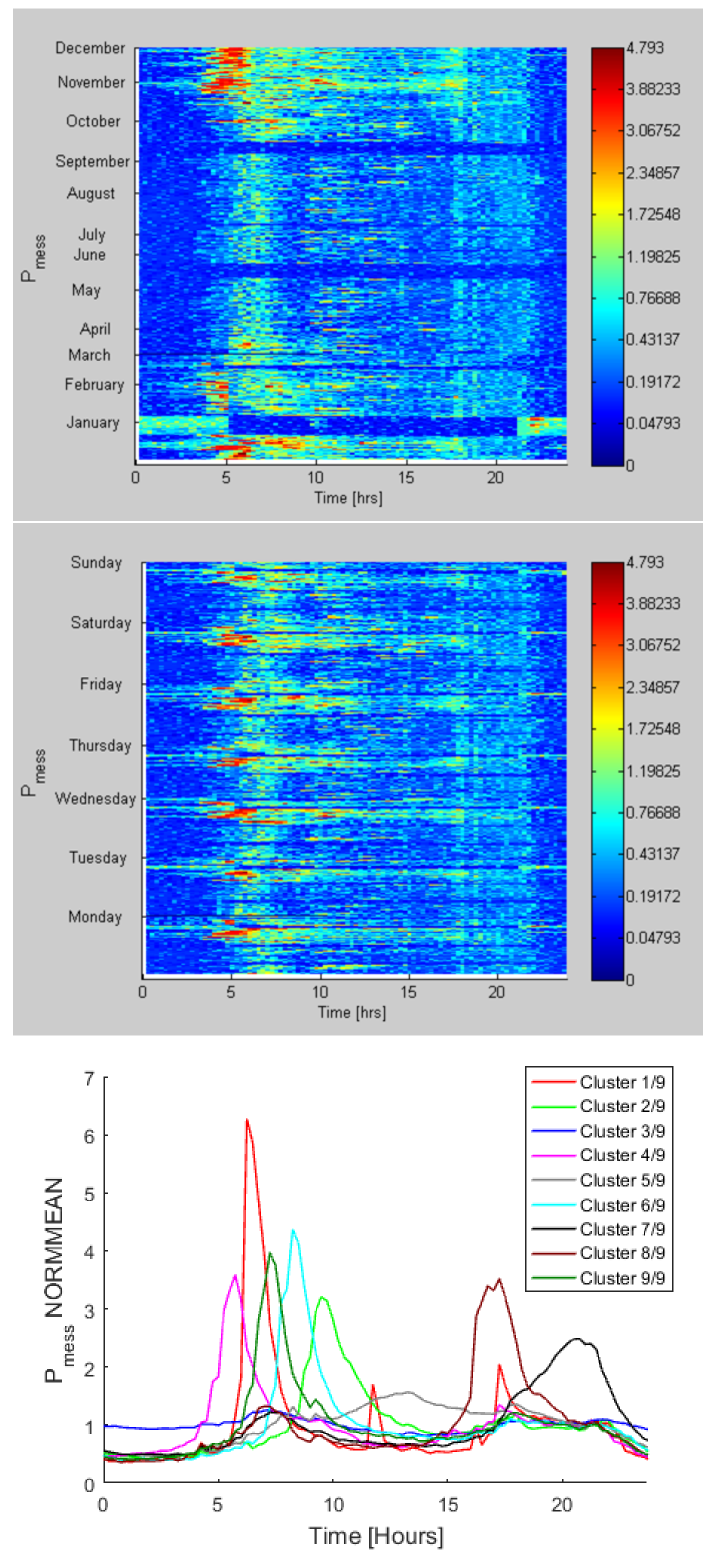


Abb. 1 Analyse des Energieverbrauchs von Daten aus dem Olympic Peninsula Datensatz [34]:
a. Visualisierung eines Beispielkunden (ID 870) als Heatmap mit farbig kodiertem Energieverbrauch, Tageskurven über Monate sortiert (oben),
b. wie a., aber über Wochentage sortiert,
c. Clusteranalyse mit 9 Clustern der normierten Energieverbrauchszeitreihen für 21894 Tageskurven verschiedener Kunden zum Identifizieren typischer Verbrauchsmuster [87]

Etagenanzahl) über umfangreiche CAD-Daten (z.B. Lage Fenster, Wanddicken). Hierfür gibt es Standards für Building Information Models, um Daten aus unterschiedlichen Systemen zusammenführen zu können, siehe z.B. [18, 27, 49, 56]. Diese Daten können dann mit Daten über die Gebäudenutzung assoziiert werden (z.B. Energieverbrauchszeitreihen in unterschiedlicher zeitlicher Auflösung, siehe 1.). Solche Daten können dann genutzt werden, um Simulationsmodelle für existierende und geplante Gebäudebestände aufzubauen, siehe z.B. [54].

3. Zusätzlich können in die Grundstruktur von Bauwerken Sensoren (z.B. Beschleunigungsmesser, Dehnmessstreifen) fest integriert werden, entweder für den Verbleib über die gesamte Lebenszeit von Gebäuden oder nur während bestimmter Phasen wie in der Bauphase. Diese Ansätze werden unter dem Namen Structural Health Monitoring (SHM) zusammengefasst [6, 22]. Gebäude können hier z.B. große Hallen mit Tragwerkskonstruktionen [70] oder Brücken [41, 75] sein. Die Sensoren müssen dazu entweder fest verkabelt werden oder über ein drahtloses System Informationen übermitteln [70, 82]. Solche Sensoren können dazu verwendet werden, unerwünschte Änderungen (z.B. Verformungen, zunehmende Schwingungen) zu erkennen. Ein Beispiel für ein solches System zeigt Abb. 2. Hier sind verschiedene Ziele denkbar, vom Langzeitmonitoring des allgemeinen Gebäudezustandes mit dem Ziel einer Schadensprognose [26] oder spezifischere Untersuchungen wie eine Korrosionsüberwachung mit mobilen oder fest installierten Messungen [38] bis hin zur Schadenserkennung nach Erdbeben [42, 81]. Aus Sicht von Datenanalysen können entweder Zeitreihen auf Trends untersucht werden oder nach Ausreißern in einem Datensatz gesucht werden, der das normale Verhalten eines Bauwerks widerspiegelt, siehe z.B. [31].

5 Smart Grids (Intelligente Netze)

Eine weitere Erhöhung der Datenmengen resultiert aus der Vernetzung vieler datengenerierender und intelligenter Komponenten zu einem Gesamtsystem. Hier wird in der Regel der Begriff Smart Grids verwendet.

Besonders populär ist dieser Begriff für das Energiesystem, weil Smart Grids als eine Schlüsseltechnologie zur Beherrschung von Systemen mit vielen lokal verteilten und fluktuierenden Einspeisungen (z.B. Solar- und Windkraftwerke) gesehen werden [25]. In Deutschland wird im Zuge der "Energiewende" ein Anteil von 80% erneuerbarer Energiequellen zur Stromerzeugung angestrebt [77]. Ein solches System muss dann durch verschiedene Maßnahmen, wie

- die Integration von Strom-, Gas-, Wärme- und Dampfnetzen inkl. der zugehörigen Datenströme,
- den Betrieb von verteilten Speichern,
- die Anpassung des Verbrauches an die jeweilige Erzeugungs- und Netzsituation (Demand Response) und
- ein geeignetes Marktdesign und geeignete regulatorische Vorgaben

stabilisiert werden. Jeder dieser Schritte erfordert das Aggregieren von Sensorinformationen, Modellierungen und Visualisierungen zum besseren Problemverständnis sowie das automa-

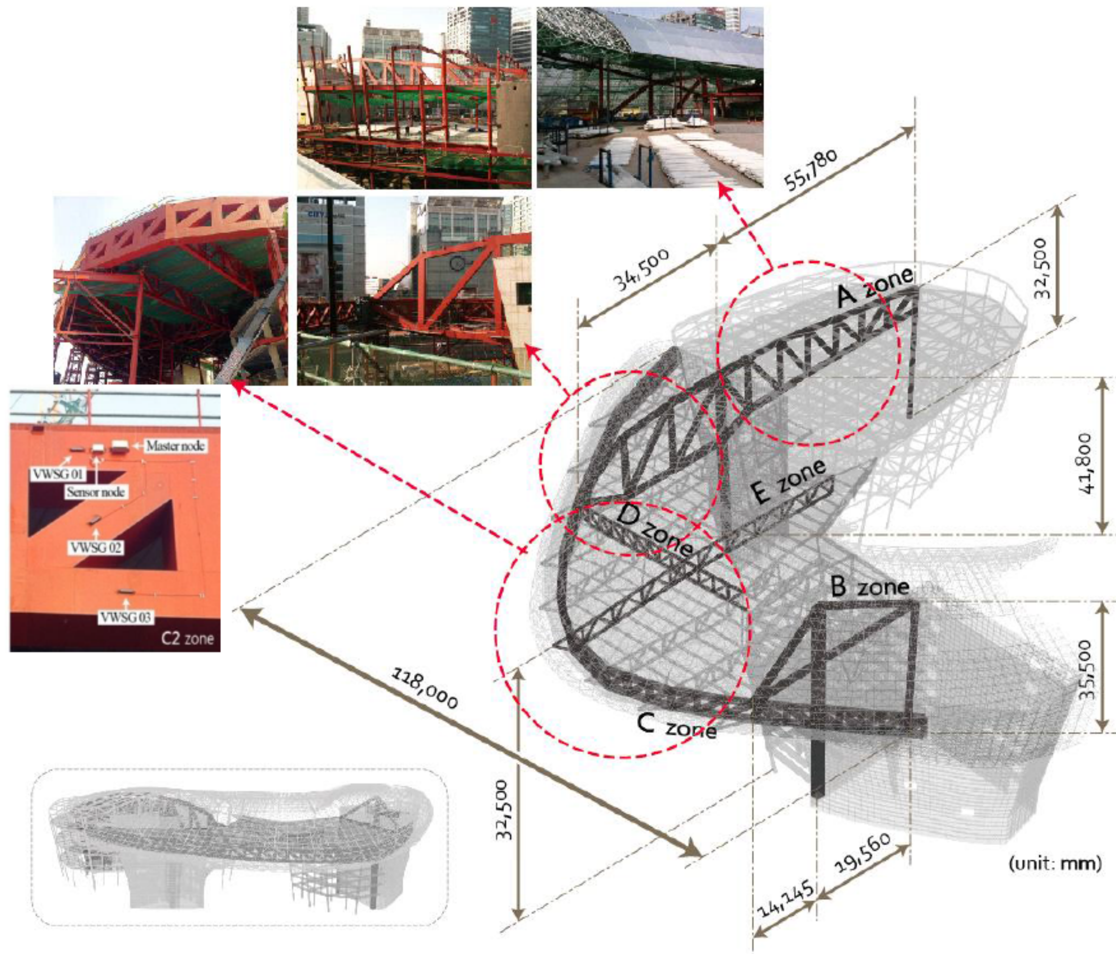


Abb. 2 Beispiel für ein Echtzeitmonitoring-System für das Design Plaza Building in Seoul/Korea, Bildquelle: modifiziert nach [70]

tische oder zumindest halbautomatische Erstellen von Prognosemodellen und deren Nutzung in Optimierungsverfahren. Hierzu laufen vielfältige Forschungsarbeiten, z.B. in Feldversuchen [37, 92] und im Energy Lab 2.0 des KIT [32].

Auch hier können intelligente Gebäude eine zentrale Rolle spielen. Beispiele hierfür sind Strategien zum Demand Response, die Energieverbraucher (z.B. Wärmepumpen, Klimaanlagen usw.) netzdienlich einsetzen, siehe z.B. [50, 69].

6 Zusammenfassung

In vielen Anwendungsgebieten haben in den letzten Jahren die gesammelten Datenmengen deutlich zugenommen. Damit besteht die Chance, dass in diesen Daten interessante Informationen enthalten sind, aus denen nützliche Erkenntnisse generiert werden können. Das setzt eine enge Zusammenarbeit von Anwendungs- und Datenanalyseexperten voraus. Prinzipiell stehen etablierte Analysemethoden bereit. Bei sehr großen Datenmengen (”Big Data”) ist speziell darauf zu achten, geeignete Methoden und Tools zu verwenden, die die gewünschten Ergebnis-

se bei akzeptablem Aufwand selbst bei zusätzlichen Schwierigkeiten wie Unsicherheiten und schlechter Datenqualität liefern. Hier besteht weiterer Forschungsbedarf, um mit den zunehmend anspruchsvolleren Anwendungen Schritt zu halten.

Der Beitrag diskutiert ausgewählte Anwendungsgebiete wie Smart Buildings und Smart Grids, in denen erste Big-Data-Aufgaben erfolgreich gelöst wurden und weitere Aufgaben vielversprechend erscheinen. Das Ziel des Beitrags bestand darin, die Sicht der Datenanalyse zu erläutern, um die Diskussion über zukünftige Aufgaben mit Experten in den jeweiligen Anwendungen anzuregen.

Danksagung: Diese Arbeit wurde von der Helmholtz-Gemeinschaft innerhalb der gemeinsamen Initiative "Energie System 2050 - Ein Beitrag des Forschungsbereichs Energie" unterstützt.

Literatur

[1] C. Aggarwal. *Data Streams: Models and Algorithms*. Springer, 2007.

[2] M. B. Ahrens, M. B. Orger, D. N. Robson, J. M. Li, and P. J. Keller. Whole-brain functional imaging at cellular resolution using light-sheet microscopy. *Nature Methods*, 10:413–420, 2013.

[3] O. Armant, M. März, R. Schmidt, M. Ferg, N. Diotel, R. Ertzer, J. C. Bryne, L. Yang, I. Baader, M. Reischl, J. Legradi, R. Mikut, D. Stemple, W. van IJcken, A. van der Sloot, B. Lenhard, U. Strähle, and S. Rastegar. Genome-wide, whole mount in situ analysis of transcriptional regulators in zebrafish embryos. *Developmental Biology*, 380(2):351–362, 2013.

[4] T. Asfour, J. Schill, H. Peters, C. Klas, J. Bucker, C. Sander, S. Schulz, A. Kargov, T. Werner, and V. Bartenbach. ARMAR-4: A 63 DOF torque controlled humanoid robot. In *Proc., 13th IEEE-RAS International Conference on Humanoid Robots*, pages 390–396. IEEE, 2013.

[5] K. Backhaus, B. Erichson, W. Plinke, and R. Weiber. *Multivariate Analysemethoden: Eine anwendungsorientierte Einführung*. Springer, Berlin u.a., 2000.

[6] D. Balageas, C.-P. Fritzen, and A. Güemes. *Structural Health Monitoring*, volume 493. Wiley Online Library, 2006.

[7] C. Batini, C. Cappiello, C. Francalanci, and A. Maurino. Methodologies for data quality assessment and improvement. *ACM Comput. Surv.*, 41(3):16:1–16:52, July 2009.

[8] C. Bauer, Z. Siddiqui, M. Beuttler, and K. Bauer. Bigdata in manufacturing systems engineering - closeup on a machine tool. *at-Automatisierungstechnik*, 64(7):534–539, 2016.

[9] T. Bauernhansl, M. Ten Hompel, and B. Vogel-Heuser. *Industrie 4.0 in Produktion, Automatisierung und Logistik*. Springer-Verlag, 2014.

[10] S. Beck, R. Mikut, A. Lehmann, and G. Bretthauer. Model-based control and object contact detection for a fluidic actuated robotic hand. In *Proc., 42nd IEEE Conference on Decision and Control*, pages 6369–6374. 2003.

[11] M. R. Berthold, N. Cebron, F. Dill, T. R. Gabriel, T. Kötter, T. Meinl, P. Ohl, C. Sieb, K. Thiel, and B. Wiswedel. KNIME: The Konstanz Information Miner. In *Data Analysis, Machine Learning and Applications*, pages 319–326. Springer, 2008.

[12] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York, 1981.

[13] I. Bird. Computing for the large hadron collider. *Annual Review of Nuclear and Particle Science*, 61:99–118, 2011.

[14] J. Bohg, A. Morales, T. Asfour, and D. Kragic. Data-driven grasp synthesis - a survey. *IEEE Transactions on Robotics*, 30(2):289–309, 2014.

[15] J. B. Bremnes. Probabilistic wind power forecasts using local quantile regression. *Wind Energy*, 7(1):47–54, 2004.

[16] C. Burges. A tutorial on support vector machines for pattern recognition. *Knowledge Discovery and Data Mining*, 2(2):121–167, 1998.

[17] O. Burmeister, M. Reischl, G. Bretthauer, and R. Mikut. Data-Mining-Analysen mit der MATLAB-Toolbox Gait-CAD. *at-Automatisierungstechnik*, 56(7):381–389, 2008.

[18] T. Cerovsek. A review and outlook for a "Building Information Model" (BIM): A multi-standpoint framework for technological development. *Advanced Engineering Informatics*, 25(2):224–244, 2011.

[19] M. Chen, S. Mao, and Y. Liu. Big data: A survey. *Mobile Networks and Applications*, 19(2):171–209, 2014.

[20] T. Cover and P. Hart. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21–27, 1967.

[21] W. Doneit, R. Mikut, T. Pychynski, and M. Reischl. Abstands- und Monotoniemaße für Regressionsmodelle mit heterogenen Lerndaten. In *Proc., 24. Workshop Computational Intelligence, Dortmund*, pages 1–16. KIT Scientific Publishing, 2014.

[22] K. Dragos and K. Smarsly. Decentralized infrastructure health monitoring using embedded computing in wireless sensor networks. In A. Sextos and G. D. Manolis, editors, *Dynamic Response of Infrastructure to Environmentally Induced Loads*. Springer International Publishing AG, Cham, Schweiz, 2016.

[23] C. Düpmeier, K.-U. Stucky, R. Mikut, and V. Hagenmeyer. A concept for the control, monitoring and visualization center in Energy Lab 2.0. In *Energy Informatics*, pages 83–94. Springer, 2015.

[24] J. H. Faghmous and V. Kumar. A big data guide to understanding climate change: The case for theory-guided data science. *Big Data*, 2(3):155–163, 2014.

[25] X. Fang, S. Misra, G. Xue, and D. Yang. Smart grid – the new and improved power grid: A survey. *IEEE Communications Surveys Tutorials*, 14(4):944–980, 2012.

[26] C. R. Farrar and N. A. Lieven. Damage prognosis: The future of structural health monitoring. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 365(1851):623–632, 2007.

[27] A. Geiger, J. Benner, and K. H. Haefele. Generalization of 3D IFC building models. In *3D Geoinformation Science*, pages 19–35. Springer, 2015.

[28] J. Á. González Ordiano, S. Waczowicz, M. Reischl, R. Mikut, and V. Hagenmeyer. Photovoltaic power forecasting using simple data-driven models without weather data. *Computer Science - Research and Development*, pages 1–10, 2016.

[29] W. Graf, S. Freitag, J.-U. Sickert, and M. Kaliske. Structural analysis with fuzzy data and neural network based material description. *Computer-Aided Civil and Infrastructure Engineering*, 27(9):640–654, 2012.

[30] C. R. Groom and F. H. Allen. The Cambridge Structural Database in retrospect and prospect. *Angewandte Chemie International Edition*, 53(3):662–671, 2014.

[31] M. Gul and F. N. Catbas. Statistical pattern recognition for structural health monitoring using time series modeling: Theory and experimental verifications. *Mechanical Systems and Signal Processing*, 23(7):2192–2204, 2009.

[32] V. Hagenmeyer, H. K. Cakmak, C. Düpmeier, T. Faulwasser, J. Isele, H. B. Keller, P. Kohlhepp, U. Kühnapfel, U. Stucky, S. Waczowicz, and R. Mikut. Information and communication technology in Energy Lab 2.0: Smart energies system simulation and control center with an Open-Street-Map-based power flow simulation example. *Energy Technology*, 4:145–162, 2016.

[33] M. A. Hamburg and F. S. Collins. The path to personalized medicine. *New England Journal of Medicine*, 363(4):301–304, 2010.

[34] D. J. Hammerstrom, R. Ambrosio, J. Brous, T. A. Carlon, D. P. Chassin, J. G. DeSteese, R. T. Guttromson, G. R. Horst, O. M. Järvegren, R. Kajfasz, et al. Pacific Northwest GridWise Testbed Demonstration Projects, part i. Olympic Peninsula Project. Technical report, Pacific Northwest National Laboratory (PNNL), Richland, Washington, 2007.

[35] I. A. T. Hashem, I. Yaqoob, N. B. Anuar, S. Mokhtar, A. Gani, and S. U. Khan. The rise of "big data" on cloud computing: Review and open research issues. *Information Systems*, 47:98–115, 2015.

[36] S. S. Haykin. *Neural Networks and Learning Machines*. Pearson Education Upper Saddle River, 2009.

[37] L. Hofmann and M. Sonnenschein. Smart Nord - final report. Technical report, Lower Saxony Research Network "Smart Nord", 2015.

[38] A. Holst, H. Budelmann, K. Hariri, and H.-J. Wichmann. Korrosionsmonitoring und Bruchortung in Spannbetonbauwerken–Möglichkeiten und Grenzen. *Beton- und Stahlbetonbau*, 102(12):835–847, 2007.

[39] F. Höppner, F. Klawonn, and R. Kruse. *Fuzzy Cluster Analysis*. John Wiley, New York, 1999.

[40] A. K. Jain, R. P. W. Duin, and J. Mao. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4–36, 2000.

[41] S. Jang, H. Jo, S. Cho, K. Mechitov, J. A. Rice, S.-H. Sim, H.-J. Jung, C.-B. Yun, B. F. Spencer Jr, and G. Agha. Structural health monitoring of a cable-stayed bridge using smart sensor technology: Deployment and evaluation. *Smart Structures and Systems*, 6(5-6):439–459, 2010.

[42] X. Jiang and H. Adeli. Pseudospectra, MUSIC, and dynamic wavelet neural network for damage detection of highrise buildings. *International Journal for Numerical Methods in Engineering*, 71(5):606–629, 2007.

[43] H. Kagermann, W. Wahlster, and J. Helbig. Umsetzungsempfehlungen für das Zukunftsprojekt Industrie 4.0: Abschlussbericht des Arbeitskreises Industrie 4.0. acatech–National Academy of Science and Engineering, 2013.

[44] A. Kavousian, R. Rajagopal, and M. Fischer. Determinants of residential electricity consumption: Using smart meter data to examine the effect of climate, building characteristics, appliance stock, and occupants' behavior. *Energy*, 55:184–194, 2013.

[45] B. Kehoe, S. Patil, P. Abbeel, and K. Goldberg. A survey of research on cloud robotics and automation. *IEEE Transactions on Automation Science and Engineering*, 12(2):398–409, 2015.

[46] S. A. Kim, D. Shin, Y. Choe, T. Seibert, and S. P. Walz. Integrated energy monitoring and visualization system for smart green city development: Designing a spatial information integrated energy monitoring model in the context of massive data management on a web based platform. *Automation in Construction*, 22:51–59, 2012.

[47] R. Kitchin. The real-time city? Big data and smart urbanism. *GeoJournal*, 79(1):1–14, 2014.

[48] A. Kobitski, J. C. Otte, M. Takamiya, B. Schäfer, J. Mertes, J. Stegmaier, S. Rastegar, F. Rindone, V. Hartmann, R. Stotzka, A. García, J. v. Wezel, R. Mikut, U. Strähle, and G. U. Nienhaus. An ensemble-averaged, cell density-based digital model of zebrafish embryo development derived from light-sheet microscopy data with single-cell resolution. *Scientific Reports*, 5(8601):1–10, 2015.

[49] M. König, E. Rank, K.-U. Bletzinger, A. Borrmann, K. Smarsly, and W. Huhnt. Aktuelle Entwicklungen und Herausforderungen der Bauinformatik. *Bauingenieur*, 90(7/8), 2015.

[50] G. Koutitas. Control of flexible smart devices in the smart grid. *IEEE Transactions on Smart Grid*, 3(3):1333–1343, 2012.

[51] I. Kovynyov, G. Devaquet, and B. Riesen. Automatisierung einer datenintensiven Leistungsabrechnung im Flughafen-Serviceumfeld. *at-Automatisierungstechnik*, 64(7):567–580, 2016.

[52] A. Kroll. *Computational Intelligence*. De Gruyter Oldenbourg, 2016.

[53] D. Laney. 3D data management: Controlling data volume, velocity and variety. Technical report, META Group Research Note, 2001.

[54] M. Lauster, M. Fuchs, J. Teichmann, R. Streblow, and D. Müller. Energy simulation of a research campus with typical building setups. In *Proc., 13th Conference of International Building Performance Simulation Association*, pages 769–775, 2013.

[55] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. *Nature*, 521(7553):436–444, 2015.

[56] M.-O. Löwner, J. Benner, G. Gröger, U. Gruber, K.-H. Häfele, and S. Schlüter. CityGML 2.0-ein internationaler Standard für 3D-Stadtmodelle, Teil 1: Datenmodell. *Zeitschrift für Geodäsie, Geoinformation und Landmanagement*, 6:340–349, 2012.

[57] D. Lyon. Surveillance, Snowden, and big data: Capacities, consequences, critique. *Big Data & Society*, 1(2):1–13, 2014.

[58] H. Maaß, H. K. Cakmak, F. Bach, R. Mikut, A. Harrabi, W. Süß, W. Jakob, K.-U. Stucky, U. G. Kühnapfel, and V. Hagenmeyer. Data processing of high rate low voltage distribution grid recordings for smart grid monitoring and analysis. *EURASIP Journal on Advances in Signal Processing*, 1:1–21, 2015.

[59] S. E. Madnick, R. Y. Wang, Y. W. Lee, and H. Zhu. Overview and framework for data and information quality research. *Journal of Data and Information Quality (JDIQ)*, 1(1):2, 2009.

[60] X. Meng, J. Bradley, B. Yuvaz, E. Sparks, S. Venkataraman, D. Liu, J. Freeman, D. Tsai, M. Amde, S. Owen, et al. MLlib: Machine learning in apache spark. *Journal of Machine Learning Research*, 17(34):1–7, 2016.

[61] D. Michie, D. Spiegelhalter, and C. Taylor. *Machine Learning, Neural and Statistical Classification*. Ellis Horwood, 1994.

[62] R. Mikut. *Data Mining in der Medizin und Medizintechnik*. Universitätsverlag Karlsruhe, 2008.

[63] R. Mikut. Big Data & Automatisierung. *at-Automatisierungstechnik*, 64(7):503–506, 2016.

[64] R. Mikut, O. Burmeister, L. Gröll, and M. Reischl. Takagi-Sugeno-Kang fuzzy classifiers for a special class of time-varying systems. *IEEE Transactions on Fuzzy Systems*, 16(4):1038–1049, 2008.

[65] R. Mikut and K. Hilpert. Interpretable features for the activity prediction of short antimicrobial peptides using fuzzy logic. *International Journal of Peptide Research and Therapeutics*, 15(2):129–137, 2009.

[66] R. Mikut and M. Reischl. Data mining tools. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(5):431–443, 2011.

[67] J. d. R. Millán, R. Rupp, G. Müller-Putz, R. Murray-Smith, C. Giugliemma, M. Tangermann, C. Vidaurre, F. Cincotti, A. Kübler, R. Leeb, et al. Combining brain–computer interfaces and assistive technologies: State-of-the-art and challenges. *Frontiers in Neuroscience*, 4:1–15, 2010.

[68] S. Naik, S. Doyle, S. Agner, A. Madabhushi, M. Feldman, and J. Tomaszewski. Automated gland and nuclei segmentation for grading of prostate and breast cancer histopathology. In *Proc., 2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, pages 284–287. IEEE, 2008.

[69] A.-G. Paetz, B. Becker, W. Fichtner, and H. Schmeck. Shifting electricity demand with smart home technologies–an experimental study on user acceptance. In *Proc., 30th USAEE/IAEE North American Conference*, volume 19, page 20, 2011.

[70] H. S. Park, Y. Shin, S. W. Choi, and Y. Kim. An integrative structural health monitoring system for the local/global responses of a large-scale irregular building under construction. *Sensors*, 13(7):9085–9103, 2013.

[71] C. Phua, D. Alahakoon, and V. Lee. Minority report in fraud detection: Classification of skewed data. *ACM SIGKDD Explorations Newsletter*, 6(1):50–59, 2004.

[72] M. A. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko. A review of novelty detection. *Signal Processing*, 99:215–249, 2014.

[73] H. Plattner. The impact of columnar in-memory databases on enterprise systems: Implications of eliminating transaction-maintained aggregates. *Proceedings of the VLDB Endowment*, 7(13):1722–1729, 2014.

[74] C. Pylatiuk, D. Sanchez, R. Mikut, R. Alshut, M. Reischl, S. Hirth, W. Rottbauer, and S. Just. Automatic zebrafish heartbeat detection and analysis for zebrafish embryos. *Zebrafish*, 11:379–383, 2014. i.

[75] J. A. Rice, K. Mechitov, S.-H. Sim, T. Nagayama, S. Jang, R. Kim, B. F. Spencer Jr, G. Agha, and Y. Fujino. Flexible smart sensor framework for autonomous structural health monitoring. *Smart Structures and Systems*, 6(5-6):423–438, 2010.

[76] L. Schmalfuß, R. Rupp, M. Tuga, A. Kogut, M. Hewitt, J. Meincke, F. Klinker, W. Duttenhoefer, U. Eck, R. Mikut, M. Reischl, and D. Liebetanz. Steer by ear: Myoelectric auricular control of powered wheelchairs for individuals with spinal cord injury. *Restorative Neurology and Neuroscience*, 34(1):79–95, 2015.

[77] R. Scholz, M. Beckmann, C. Pieper, M. Muster, and R. Weber. Considerations on providing the energy needs using exclusively renewable sources: Energiewende in Germany. *Renewable and Sustainable Energy Reviews*, 35:109–125, 2014.

[78] K. A. Smith, R. J. Willis, and M. Brooks. An analysis of customer retention and insurance claim patterns using data mining: A case study. *Journal of the Operational Research Society*, 51(5):532–541, 2000.

[79] J. Stegmaier, F. Amat, W. B. Lemon, K. McDole, Y. Wan, G. Teodoro, R. Mikut, and P. J. Keller. Real-time three-dimensional cell segmentation in large-scale microscopy data of developing embryos. *Developmental Cell*, 36(2):225–240, 2016.

[80] J. Stegmaier, B. Schott, E. Hübner, M. Traub, M. Shahid, M. Takamiya, A. Kobitski, V. Hartmann, R. Stotzka, J. van Wezel, A. Streit, G. U. Nienhaus, U. Strähle, M. Reischl, and R. Mikut. Automation strategies for large-scale 3D image analysis. *at-Automatisierungstechnik*, 64(7):555–566, 2016.

[81] M. I. Todorovska and M. D. Trifunac. Earthquake damage detection in the Imperial County Services Building II: Analysis of novelties via wavelets. *Structural Control and Health Monitoring*, 17(8):895–917, 2010.

[82] T. Torfs, T. Sterken, S. Brebels, J. Santana, R. van den Hoven, V. Spiering, N. Bertsch, D. Trapani, and D. Zonta. Low power wireless sensor network for building monitoring. *IEEE Sensors Journal*, 13(3):909–915, 2013.

[83] Z. Tufekci. Big questions for social media big data: Representativeness, validity and other methodological pitfalls. In *Proc., 8th International AAAI Conference on Weblogs and Social Media*, 2014.

[84] S. Van Dam, C. Bakker, and J. Van Hal. Home energy monitors: Impact over the medium-term. *Building Research & Information*, 38(5):458–469, 2010.

[85] W. M. van der Aalst, H. A. Reijers, A. J. Weijters, B. F. van Dongen, A. A. De Medeiros, M. Song, and H. Verbeek. Business process mining: An industrial application. *Information Systems*, 32(5):713–732, 2007.

[86] J. C. Venter and et al. The sequence of the human genome. *Science*, 291 (5507):1304–1351, 2001.

[87] S. Waczowicz, S. Klaiber, P. Bretschneider, I. Konotop, D. Westermann, M. Reischl, and R. Mikut. Data mining to analyse the effects of price signals on household electricity customers. *at-Automatisierungstechnik*, 62(10):740–752, 2014.

[88] P. L. Wagner, A.-C. Stiedl, T. Wilbertz, K. Petersen, V. Scheble, R. Menon, M. Reischl, R. Mikut, M. A. Rubin, F. Fend, et al. Frequency and clinicopathologic correlates of KRAS amplification in non-small cell lung carcinoma. *Lung Cancer*, 74(1):118–123, 2011.

[89] J. S. Ward and A. Barker. Undefined by data: A survey of big data definitions. Technical report, arXiv preprint arXiv:1309.5821, 2013.

[90] M. Werling, B. Gutjahr, S. Galler, and L. Gröll. Riccati-Trajektorienoptimierung für den aktiven Fußgängerschutz. *at-Automatisierungstechnik*, 63(3):202–210, 2015.

[91] D. Wijayasekara, O. Linda, M. Manic, and C. Rieger. Mining building energy management system data using fuzzy anomaly detection and linguistic descriptions. *IEEE Transactions on Industrial Informatics*, 10(3):1829–1840, 2014.

[92] M. Witzsch. Microgrid im Allgäu verändert Zukunft der Stromversorgung. *ew-Magazin für die Energiewirtschaft*, pages 51–53, 6 2015.

[93] S. I. Wolf, R. Mikut, A. Kranzl, and T. Dreher. Which functional impairments are the main contributors to pelvic anterior tilt during gait in individuals with cerebral palsy? *Gait & Posture*, 39(1):359–364, 2014.

[94] S. Wrobel, H. Voss, J. Köhler, U. Beyer, and S. Auer. Big Data, Big Opportunities, Anwendungssituation und Forschungsbedarf des Themas Big Data in Deutschland. *Informatik-Spektrum*, 38(5):1–9, 2014.